

耦合横纵向个体更新策略的改进MVO算法

赵世杰, 高雷阜[†], 徒 君, 于冬梅

(辽宁工程技术大学 优化与决策研究所, 辽宁 阜新 123000)

摘要: 为提高多元宇宙优化算法(MVO)的全局探索和局部开采性能,提出一种耦合横纵向个体更新策略的改进MVO算法(IMVO). 横向更新策略是建立在宇宙种群层级的一种水平迁移进化机制,通过引入加权学习因子保证子代个体同时向多个父代宇宙继承位置信息,以改善种群的个体多样性和算法全局探索性能,适定性修正虫洞存在概率表达以保证种群个体间的充分信息交互;纵向更新策略是基于宇宙个体层级的一种纵向自我学习进化机制,根据最优宇宙历史信息,通过模拟认知的历史遗忘记忆特性实现记忆均值邻域的再开采,以增强算法局部开采性能. 最后通过数值实验验证不同加权学习因子函数对算法性能的差异性影响,改进算法的优化性能和算法稳健性等.

关键词: 多元宇宙优化算法; 元启发式优化算法; 横纵向个体更新策略; 历史遗忘记忆特性; 基准测试函数
中图分类号: TP18 **文献标志码:** A

Improved multi verse optimizer coupling horizontal-and-vertical individual updated strategies

ZHAO Shi-jie, GAO Lei-fu[†], TU Jun, YU Dong-mei

(Institute of Optimization and Decision, Liaoning Technical University, Fuxin 123000, China)

Abstract: To enhance global exploration and local exploitation performance of the multi verse optimizer(MVO), the improved multi verse optimizer(IMVO) is proposed by coupling horizontal and vertical individual updated strategies. The horizontal updated strategy is a horizontal migration evolution mechanism on the population level, in which population diversification and global exploration performance can be improved by introducing the weighted learning factor(WLF) to guarantee that offspring individuals inherit position information from multiple universes of parent generation simultaneously. The mathematical expression of wormhole existence probability is amended properly to heighten information exchange among individuals. Moreover, the vertical updated strategy is a vertical self-learning evolution mechanism on individual level, in which local exploitation performance can be modified by simulating the history forgotten memory characteristic of human cognition to ensure that the neighbourhood of memory mean position based on history information of best universes is re-exploited. Experimental results verify the performance influence of difference WLF functions on the IMVO, and the better optimization performance and robustness of the proposed algorithm.

Keywords: multi verse optimizer; meta-heuristic optimization algorithms; horizontal-and-vertical individual updated strategies; history forgotten memory characteristic; benchmark functions

0 引言

仿生智能算法(元启发式优化算法)是受特定自然现象/规律启发而提出的一类基于群体的随机优化技术,其以初值不敏感性且不依赖于梯度信息、机理简单易理解等特点成为确定性优化算法求解非线性、

多约束问题的一种较好替代,目前已成功应用于图像识别^[1]、机械设计^[2]、回归预测^[3]等领域.

根据算法启发机理的差异,仿生智能算法大致可分为3类:基于遗传进化的算法、基于生物群体的算法和基于特定物理机理的算法. 其中:基于遗传进

收稿日期: 2017-04-14; 修回日期: 2017-07-05.

基金项目: 国家自然科学基金项目(51704140); 辽宁省教育厅基金项目(L2015208, LJYL043); 教育部高等学校博士学科点专项科研基金联合项目(20132121110009).

责任编辑: 林崇.

作者简介: 赵世杰(1987—),男,博士生,从事人工智能与数据挖掘、优化与管理决策的研究; 高雷阜(1963—),男,教授,博士生导师,从事最优化理论与方法、非线性动力系统等研究.

[†]通讯作者. E-mail: gaoleifu@163.com

化的算法有推演生物进化、遗传变异机制的进化策略^[4](ES)、遗传算法^[5](GA)等;基于生物群体的算法有模拟鸟群捕食、蚁群觅食行为的粒子群优化算法^[6](PSO)、蚁群算法^[7](ACO)等;基于物理机理的算法有模仿固体退火、万有引力原理的模拟退火算法^[8](SA)、引力搜索算法^[9](GSA)等。鉴于仿生算法具有较好的并行寻优性能以及人们对自然现象/机理的不断探究,新智能算法也不断被构造,如模拟不同电极磁场行为的电磁场优化算法^[10](EFO)、平衡域探索与开采性能的搜索群组算法^[11](SGA)、基于乌鸦智能行为的乌鸦搜索算法^[12](CSA)、源于蜻蜓集群行为的蜻蜓算法^[13](DA)等。

多元宇宙优化算法^[14](MVO)是Seyedali提出的一种基于物理机理的新算法,其源于多元宇宙理论中黑白洞及虫洞概念,通过模拟白(黑)洞发送(吸引)物体、虫洞瞬时输送物体等机理实现搜索空间的迭代探索与开采优化,其启发机理简单、待调节参数少、探索开采性能强等优点已在机械结构优化设计^[14]、模型参数优化选择^[15]、光子晶体滤波器设计^[16]等领域得到应用。

为提高传统MVO算法的迭代寻优能力,本文提出一种耦合横纵向个体更新策略的改进MVO算法(IMVO)。横向更新策略通过引入加权学习因子使子代新个体同时继承父代多个宇宙个体的位置信息并生成新位置,同时适应性修正WEP的递变形式以改善宇宙种群个体间的位置信息交流和算法优化能力;纵向更新策略则是通过拟合人脑认知的历史遗忘记忆特性对最优宇宙个体记忆邻域进行再开采,以增强算法的局部搜索性能。最后通过数值实验验证改进策略的有效性和可行性。

1 多元宇宙优化算法(MVO)^[14]

MVO算法的思想启发于物理学中多元宇宙理论,通过对白/黑洞(宇宙)和虫洞等概念及其相互作用机理的数学化描述实现待优化问题的求解,其中宇宙代表问题可行解,宇宙中物体代表解的分量,宇宙膨胀率代表解的适应度值。

在每次迭代时,首先依宇宙膨胀率排序种群个体,轮盘赌随机选定一个宇宙作为白洞,通过虫洞实现白-黑洞间物体交换。为便于数学化描述,假定

$$U = \begin{bmatrix} x_1^1 & x_1^2 & \cdots & x_1^d \\ x_2^1 & x_2^2 & \cdots & x_2^d \\ \vdots & \vdots & \ddots & \vdots \\ x_n^1 & x_n^2 & \cdots & x_n^d \end{bmatrix}. \quad (1)$$

其中: d 为变量数目, n 为宇宙(候选解)数目,则

$$x_i^j = \begin{cases} x_k^j, & r_1 < \text{NI}(U_i); \\ x_i^j, & r_1 \geq \text{NI}(U_i). \end{cases} \quad (2)$$

其中: x_i^j 为第*i*个宇宙第*j*维分量, U_i 和 $\text{NI}(U_i)$ 分别为第*i*个宇宙和其归一化膨胀率, x_k^j 为轮盘赌选定的第*k*个宇宙第*j*维分量, r_1 为 $[0, 1]$ 内的一个随机数。

假定每个宇宙都拥有虫洞并随机传送物体以保证种群多样性,且与当前最优宇宙建立虫洞并交换局部物体以概率提高膨胀率。该机理数学表达为

$$x_i^j = \begin{cases} \begin{cases} X_j + \text{TDR} \cdot \delta, & r_3 < 0.5, \\ X_j - \text{TDR} \cdot \delta, & r_3 \geq 0.5, \end{cases} & r_2 < \text{WEP}; \\ x_i^j, & r_2 \geq \text{WEP}. \end{cases} \quad (3)$$

其中: x_i^j 和 X_j 分别为第*i*个宇宙和当前最优宇宙的第*j*维分量, ub_j 和 lb_j 分别为第*j*维分量的上下界, $r_2 \sim r_4$ 均为 $[0, 1]$ 内的随机数。WEP和TDR是MVO算法的两个模型控制参数:WEP表示宇宙种群的虫洞存在比例,且其值随迭代进程线性递增;TDR表示物体绕当前最优宇宙的旅行距离比例,且其值随迭代递减,其数学定义式分别为

$$\begin{aligned} \text{WEP} &= \text{WEP}_{\min} + l \times \left(\frac{\text{WEP}_{\max} - \text{WEP}_{\min}}{L} \right), \\ \text{TDR} &= 1 - \frac{l^{1/p}}{L^{1/p}}. \end{aligned} \quad (4)$$

其中: WEP_{\max} 和 WEP_{\min} 分别为参数WEP取值的上下界; l 和 L 分别为当前迭代步和最大迭代步; p 为MVO算法的开采精度, p 值越大精度越高。

MVO算法的优化进程始于种群的随机初始化,通过多个宇宙的并行迭代搜索最终得到问题的近似最优解。其中,虫洞类似于GA算法的交叉算子。

2 改进多元宇宙优化算法(IMVO)

传统MVO算法中,宇宙种群个体的更新主要根据膨胀率大小轮盘赌选定宇宙并以比较概率交换其部分物体(即某些变量分量),再根据参数WEP以比较概率围绕当前最优宇宙进行局部分量的随机更新。这些策略都是基于种群个体的代间迭代更新,且个体位置优劣直接影响算法的寻优性能。由于寻优前期最优宇宙位置往往离真实最优解相对较远,过多地围绕最优宇宙更新种群势必会增加算法陷入局部极值和种群早熟的可能性;因传统MVO算法未在最优化位置的微小邻域进行纵向深度再开采,无形中会延缓甚至错过全局最优解。鉴于上述分析,提出一种耦合横纵向个体更新策略的改进MVO算法(IMVO)以提高算法的全局探索和局部开采性能。

2.1 代间个体的横向更新策略

横向更新策略是一种种群层级的个体代间水平迁移进化机制,通过增加种群多样性以改善算法全局探索性能. 在传统MVO算法中,宇宙个体根据参数WEP与随机数 r_2 的比较判断并基于式(2)和(3)迭代生成新宇宙种群:当 $r_2 < \text{WEP}$ 时,子代个体 x_i 将围绕最优宇宙 X 在 δ 旅行域内随机更新第 j 维分量;反之,子代 x_i 按式(2)更新位置.

在MVO迭代前期,参数WEP以较大概率小于随机数 r_2 且当前最优宇宙 X 通常远离全局最优解,过于继承 X 信息势必会导致宇宙种群过快趋于同化而不利于种群多样性保持;在迭代后期,宇宙种群代间信息继承的累积效应使得宇宙个体高度同化且差异性小,此时向轮盘赌宇宙 x_k 学习的有效信息(信息熵)较少且难以显著改善算法局部开采能力. 因此,为保证宇宙种群多样性并拓宽单一宇宙继承的有限搜索域,通过引入加权学习因子 ω 保证子代宇宙同时继承最优宇宙(或自身)和轮盘赌宇宙的位置信息并生成新宇宙种群,其表达式为

$$x_i^j = \begin{cases} \begin{cases} (1-\omega)X_j + \omega x_k^j + \text{TDR} \cdot \delta, & r_3 < 0.5, \\ (1-\omega)X_j + \omega x_k^j - \text{TDR} \cdot \delta, & r_3 \geq 0.5, \end{cases} & r_2 < \text{WEP}; \\ \omega x_i^j + (1-\omega)x_k^j, & r_2 \geq \text{WEP}. \end{cases} \quad (5)$$

其中: x_k 为轮盘赌选定宇宙的位置, $\omega \in [0, 1]$ 为加权学习因子,且其值随迭代 l 呈线性或非线性递减. 形式上,式(5)可退化为式(2)与(3)的综合效用:在 $r_2 \geq \text{WEP}$ 且 $\omega = 0$ (或1)时,宇宙 x_i 的第 j 维分量保持不变(或与宇宙 x_k 的第 j 维交换),该作用等效于式(2);在 $r_2 < \text{WEP}$ 且 $\omega = 0$ 时,宇宙 x_i 在最优宇宙 X 的 δ 旅行邻域内更新第 j 维分量,该作用等效于式(3). 因此,该横向更新策略是传统MVO算法个体更新方式的拓展,可有效改善宇宙种群多样性.

不同 ω 递变形式将引起IMVO算法寻优性能的差异. 为保证IMVO较好的前期全局探索和后期局部开采性能, ω 在迭代前期应维持一个相对较大值且随迭代进程递减,根据该递变规则定义3种 ω 函数:

$$\omega = \omega_{\max} - l \times \left(\frac{\omega_{\max} - \omega_{\min}}{L} \right); \quad (6)$$

$$\omega = (\omega_{\max} - \omega_{\min}) \times \left(1 - \left(\frac{l}{L} \right)^\eta \right)^{1/\eta} + \omega_{\min}; \quad (7)$$

$$\omega = \omega_{\max} - \log(1 + q \times e^{\alpha - \frac{\beta}{l^T}}). \quad (8)$$

其中: ω_{\max} 和 ω_{\min} 分别为预设的 ω 最大值和最小值.

式(6)为线性递减型(LDT), ω 随迭代呈线性递减. 式(7)为抛物递减型(PDT), ω 随迭代呈凹形递减(即先缓慢再加速减小);系数 $\eta \geq 1$,当 $\eta = 1$ 时,式(7)将退化为式(6). 式(8)是根据文献[17]中倒S型曲线模型,经对数化处理和变换后得到的反S形递减型(ISDT), ω 随迭代呈先凹形后凸形递减,常数 q 和 β 均大于0且 $\alpha \in R$.

图1为基于横向更新策略的2维宇宙个体更新示意图(以交换第2维度 x_2 为例). 显然,基于式(5)的横向个体更新策略直观上能够寻得更广的新个体潜在位置,有利于保证宇宙种群多样性,且 ω 作用域随迭代进程缩小以保证算法最终收敛逼近于最优解.

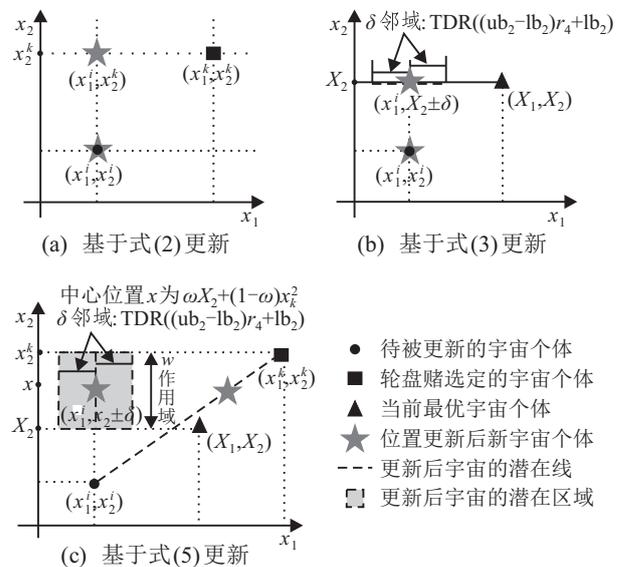


图1 MVO算法基于横向个体更新策略的2维宇宙个体更新位置

MVO算法中WEP控制着子代宇宙个体选择性更新或交换第 j 维分量,鉴于此功能,WEP可以看作是宇宙种群个体间的信息交流概率:WEP越大表示宇宙个体间信息交流越多,反之越少. 根据式(4)中WEP定义式和基本概率知识可知:WEP随迭代 l 由 $\text{WEP}_{\min} \rightarrow \text{WEP}_{\max}$ 线性递增,在迭代前期(l 值较小),WEP以较大概率小于随机数 r_2 的期望(0.5)而保持维度 j 不变,后期则以较大概率交换维度 j . 但该WEP表达并不利于算法前期个体间位置信息的充分交流且后期因种群同化已失去维度 j 交换的意义,因此,为增强MVO算法的群间位置信息交互和算法迭代寻优性能,借鉴反S递变思想提出一种适定的WEP表达式

$$\text{WEP} = \text{WEP}_{\max} - \log(1 + q \times e^{\alpha - \frac{\beta}{l^T}}). \quad (9)$$

其中:为保证WEP递变区间与文献[14]中一致,设 $q = 20, \beta = 0.7924$ 和 $\alpha = -2$.

2.2 最优个体的纵向更新策略

纵向更新策略是一种个体层级的最优个体纵向自我学习进化机制,通过最优宇宙邻域的再搜索以增强算法的局部开采性能. 最优宇宙 X 代表当前宇宙种群的最优位置,随着迭代的进行, l 逐渐逼近于全局最优解 X^* (即与 X^* 的邻域半径越趋减小),并引领宇宙种群的进化方向. 因此,为进一步增强MVO算法的局部搜索能力,需对最优宇宙 X 邻域进行再开采.

模仿人脑对先验知识的有限理性认知和历史信息的遗忘记忆特点,构造基于最优宇宙 X 历史序列的纵向个体更新策略: X 通过对自身历史先验位置的学习及微小邻域的再搜索以实现自我学习能力. 邻域是基于 X 历史位置序列的动态迭代半径,搜索中心是相应的位置加权均值,表示新开采个体大多向当前最优宇宙学习并遗忘性继承历史 X 的位置信息. 该策略不仅能保证当前最优解邻域的再次开采,而且可有效增强算法逃逸局部极值的能力. 基于历史遗忘记忆特性的最优个体 X 纵向更新函数为

$$x_{new}^m = \frac{\sum_{s=1}^N \lambda_s X_s}{N} \pm \sqrt{\frac{\sum_{s=1}^N (\bar{X} - X_s)^2}{N}}, \quad m = 1, 2, \dots, M. \quad (10)$$

其中: N 为新搜索个体 x_{new}^m 对 X 历史序列的最大记忆尺度, $\lambda_s \in (0, 1)$ 为 x_{new}^m 对历史 X 的记忆权值(水平), \bar{X} 和 X_s 分别为最优宇宙记忆尺度序列的算术均值和第 s 个宇宙, m 为记忆邻域的再搜索次数. 称 $\frac{\sum_{s=1}^N \lambda_s X_s}{N}$ 和 $\sqrt{\frac{\sum_{s=1}^N (\bar{X} - X_s)^2}{N}}$ 分别为基于最优宇宙历史记忆序列的加权均值和搜索邻域(简称为记忆均值 \bar{X} 和记忆邻域 δ'). 按照Ebbinghaus遗忘曲线的递减特点,参考文献[18]可得记忆水平 λ_s 的定义式表示为

$$\lambda_s = \frac{(l_{current} - s)^{-\kappa}}{\sum_{s=1}^N (l_{current} - s)^{-\kappa}}, \quad s = 1, 2, \dots, N. \quad (11)$$

其中: $l_{current} \in [N, L]$ 为当前迭代次数, $\kappa > 0$ 为非线性遗忘因子. κ 值越大,遗忘影响越强,新宇宙个体对历史信息的认知水平和累积学习能力越弱.

图2为基于最优宇宙纵向更新策略的局部再开采示意(以 $N = 5$ 为例). 由图2可知:纵向个体更新策略不仅能实现记忆均值 \bar{X} 的 δ' 邻域再开采,而且可增强算法局部极值逃逸能力并最终逼近全局最优解.

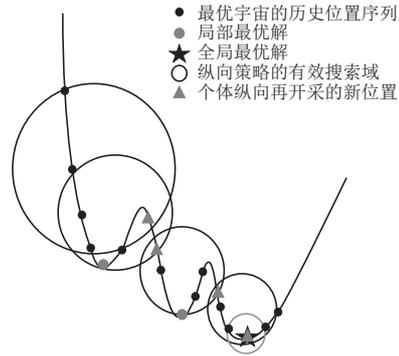


图2 基于最优宇宙纵向更新策略的个体更新

2.3 IMVO算法执行流程

IMVO算法迭代寻优进程的主要步骤如下.

Step 1: 设置模型参数. 包括宇宙规模 $Size_{pop}$, 最大迭代步 L , ω 函数的相关参数, 再开采策略的表达参数和待优化变量 x 的上下界 ub 和 lb 等.

Step 2: 初始化宇宙种群. 在区间 $[lb, ub]$ 内随机生成 $Size_{pop}$ 个宇宙个体, 并按膨胀率最小化(最大化)为优化原则确定初始最优目标值和最优宇宙.

Step 3: 宇宙种群的个体横向更新与进化. 按式(4)、(6)~(9)随迭代 l 动态更新 TDP、 ω 和 WEP, 并按式(5)横向更新个体并进化生成子代宇宙种群.

Step 4: 计算宇宙膨胀率并保存最优宇宙个体. 按待优化目标分别计算 $Size_{pop}$ 个宇宙个体的膨胀率, 依优化原则确定当前最优宇宙个体及解信息.

Step 5: 当前最优宇宙个体的纵向更新. 当最优宇宙的历史序列达到记忆尺度 N 后, 按式(10)和(11)对记忆均值 \bar{X} 的记忆邻域 δ' 进行 M 次纵向局部再开采, 并按优化原则比较更新最优宇宙个体.

Step 6: 判定当前迭代步 l 是否达到 L : 若是, 则算法终止并输出最优膨胀率和最优宇宙的解信息; 反之, 则迭代步 $l \leftarrow l + 1$ 并跳转执行 Step 3.

3 数值实验

为探究和验证IMVO算法的寻优性能,共进行两组实验:第1组实验利用基准测试函数测试不同 ω 递变函数对IMVO算法的性能影响;第2组实验通过与其他智能算法的对比实验验证IMVO的较强优化性能. 以2.6 GHz Inter(R) core(TM) i53230M CPU 4 G内存PC机为实验平台并以Matlab7.13编程实现.

3.1 不同 ω 递变函数的测试实验

为测试不同 ω 函数对IMVO算法的寻优性能影响,以6组基准测试函数进行实验,具体函数信息见表1,理论最优值均为0. 其中:前3组为单峰函数,以测试算法局部开采性能和收敛效率等;后3组为多峰函数,以测试算法全局探索性能和局部极值规避性等.

表1 基准测试函数

Name	Function	Range	
Ellipsoid	$F_1(x) = \sum_{i=1}^d ix_i^2$	[-10, 10]	单峰
Power	$F_2(x) = \sum_{i=1}^d x_i ^{i+1}$	[-1, 1]	单峰
Elliptic	$F_3(x) = \sum_{i=1}^d (10^6)^{\frac{i-1}{d-1}} x_i^2$	[-100, 100]	单峰
Alpine	$F_4(x) = \sum_{i=1}^d x_i \sin(x_i) + 0.1x_i $	[-10, 10]	多峰
Ackley	$F_5(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{d} \sum_{i=1}^d x_i^2}\right) - \exp\left(\frac{1}{d} \sum_{i=1}^d \cos 2\pi x_i\right) + 20 + e$	[-32, 32]	多峰
Penalized1	$F_6(x) = \frac{\pi}{d} \left\{ 10 \sin(\pi y_1) + \sum_{i=1}^{d-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_d - 1)^2 \right\} + \sum_{i=1}^d \mu(x_i, 10, 100, 4), y_i = 1 + \frac{x_i + 1}{4}, \mu(x_i, a, k, m) = \begin{cases} k(x_i - a)^m, & x_i > a; \\ 0, & -a < x_i < a; \\ k(-x_i - a)^m, & x_i < -a. \end{cases}$	[-50, 50]	多峰

实验中IMVO算法的宇宙种群Size_{pop}和最大迭代步L均设为20和500,加权学习因子 ω 的 ω_{\max} 和 ω_{\min} 设为0.95和0.05,设PDT型函数中 $\eta = 2$,且为保证ISDT型函数在最大迭代步L处逼近于 ω_{\min} 而设定 $q = 20, \alpha = -2$ 和 $\beta = 0.61757$.实验中,测试函数的变量维度d均设为10,各实验组均独立进行30次,并以30次实验结果的均值(Mean)、标准差(Std)、最优值(Best)、最差值(Worse)和t-test的p-Value为评价指标,具体实验统计结果见表2.

表2 不同 ω 递变函数的IMVO实验结果对比

f	Type	Mean	Std	Worse	Best	p-Value
F ₁	LDT	1.01e-07	7.60e-08	2.69e-07	2.68e-09	5.56e-08
	PDT	2.41e-06	2.43e-06	9.95e-06	2.48e-07	7.69e-06
	ISDT	4.48e-08	5.92e-08	2.26e-07	1.81e-10	2.70e-04
F ₂	LDT	3.26e-21	9.02e-21	4.42e-20	5.32e-26	5.69e-02
	PDT	7.37e-13	1.46e-12	6.30e-12	2.31e-18	9.96e-03
	ISDT	7.10e-23	1.89e-22	9.84e-22	4.61e-27	4.85e-02
F ₃	LDT	2.15e+03	2.46e+03	7.95e+03	8.14e-04	4.63e-05
	PDT	4.71e+04	3.75e+04	1.24e+05	2.31e-01	1.45e-07
	ISDT	4.51e+02	6.76e+02	2.97e+03	1.07e-04	1.01e-03
F ₄	LDT	1.14e-04	1.48e-04	7.47e-04	1.04e-05	2.27e-04
	PDT	2.48e-03	9.69e-03	5.37e-02	5.95e-05	1.71e-01*
	ISDT	8.07e-05	1.04e-04	5.28e-04	3.75e-06	2.09e-04
F ₅	LDT	4.77e-04	2.28e-04	9.66e-04	9.53e-05	2.80e-12
	PDT	2.26e-03	9.87e-04	4.93e-03	8.78e-04	3.09e-13
	ISDT	3.03e-04	1.44e-04	5.94e-04	1.03e-04	2.42e-12
F ₆	LDT	1.47e-08	1.63e-08	5.63e-08	1.12e-09	2.88e-05
	PDT	3.09e-07	2.53e-07	1.01e-06	2.08e-08	2.51e-07
	ISDT	6.47e-09	4.99e-09	1.80e-08	1.95e-10	8.05e-08

由表2分析可知:18组实验统计结果的p-Value均明显小于0.1(除F₄的PDT组),表明各组独立实验均有较高统计显著性水平.不同 ω 函数影响IMVO算法的寻优性能:在相同 ω 递变区间内,ISDT型IMVO算法(I²MVO)在Mean、Std、Best和Worse等4项指标上几乎均取得最优结果(占比23/24),LDT-IMVO算法次之,PDT-IMVO算法虽相对弱于两者,但仍保持较高的寻优精度.为更直观地对比3种IMVO算法的迭代优化进程差异,绘制迭代寻优对比曲线如图3所示.

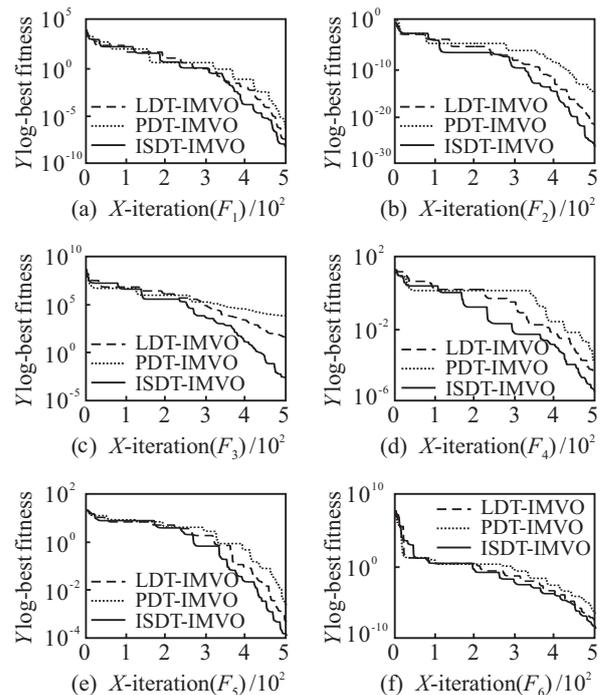


图3 不同 ω 递变函数对IMVO算法迭代优化性能的影响

由图3分析可知: 基于不同 ω 递变函数的IMVO算法对6组测试函数的迭代优化进程有所差异且迭代曲线形态各异: 迭代前期3种算法全局探索性能差异不显著, 以PDT-IMVO算法表现最优异, I²MVO算法次之; 随迭代进程推进, 特别是后期, 算法局部开采性能差异性越趋显著, I²MVO算法明显优越于其他两种算法, 并保持强劲的继续寻优潜能, LDT-IMVO算法也明显优于PDT-IMVO算法, 表明反S型IMVO算法前期全局探索性能好且后期局部开采性能强. 鉴于I²MVO算法的较好性能表现, 下节以其为改进算法与其他智能算法进行对比实验.

3.2 不同智能算法的性能对比实验

为进一步验证I²MVO算法的较好迭代优化性能, 利用4.1节测试函数以SGA^[11]、DA^[13]、CSA^[12]以及MVO^[14]为对比算法进行实验. 实验中, 种群规模

Size_{pop}和最大迭代步 L 均设为40和500, 其他参数置为: SGA中 α 初值和最小值分别为2和0.01、全局搜索进程占比为0.3、搜索群组比率为0.1, 突变体数目 n_{mut} 为5; CSA中认知概率AP为0.1、飞行距离fl为2. 各组实验均独立运行30次, 评价指标同3.1节, 实验统计结果见表3.

由表3分析可知: I²MVO算法 t -test的 p -Value均小于0.1, 表明改进算法具有较高的统计显著性水平. I²MVO算法的Mean、Std、Best和Worse等4项指标均明显优于其他4种对比算法, 如 F_2 函数高出近20个数量级; 最优Mean和Std指标表明, I²MVO算法具有较好的平均寻优性能和算法稳健性, 最优Best和Worse指标验证了测试中改进算法的极端优化性能——较强的最优解搜索能力和最坏情形下较高的寻优精度(仍优于对比算法Best指标). 从函数单多峰角度分析, 以验证改进算法的较好全局探索和局部开采性能及局部极值规避性等. 迭代优化对比曲线见图4.

表3 不同算法测试实验的统计结果对比

f	Type	Mean	Std	Worse	Best	p -Value
F_1	SGA	1.42e-05	1.05e-05	4.49e-05	2.37e-06	3.51e-08
	DA	4.45e-01	1.32e+00	6.79e+00	1.18e-06	8.95e-03
	CSA	1.31e-02	2.12e-02	1.03e-01	7.56e-05	2.13e-03
	MVO	6.91e-04	3.83e-04	1.73e-03	1.00e-4	8.64e-11
	IMVO	6.07e-10	8.54e-10	4.10e-09	2.97e-11	5.34e-04
F_2	SGA	7.57e-08	3.70e-08	1.57e-07	5.09e-09	4.77e-12
	DA	2.78e-06	1.25e-05	5.83e-05	2.95e-13	9.00e-04
	CSA	2.51e+00	8.33e+00	3.55e+01	9.51e-08	1.08e-01*
	MVO	2.17e-08	1.96e-08	7.27e-08	1.37e-11	1.35e-06
	IMVO	1.66e-27	5.19e-27	2.83e-26	1.68e-32	8.91e-02
F_3	SGA	2.48e+05	1.66e+05	6.02e+05	2.43e+04	5.04e-09
	DA	1.13e+06	1.43e+06	5.21e+06	4.73e+02	1.61e-04
	CSA	1.45e+04	9.36e+03	3.63e+04	1.23e+03	2.09e-09
	MVO	7.23e+04	4.73e+04	2.23e+05	1.57e+04	3.20e-09
	IMVO	9.73e-05	1.97e-04	8.92e-04	1.04e-06	1.16e-02
F_4	SGA	4.15e-03	4.82e-03	1.94e-02	1.84e-04	5.58e-05
	DA	1.36e+00	1.54e+00	5.72e+00	2.11e-03	3.95e-05
	CSA	9.00e-01	9.63e-01	3.59e+00	3.74e-04	1.82e-05
	MVO	1.70e-01	1.64e-01	6.81e-01	6.45e-03	3.95e-06
	IMVO	5.24e-06	4.68e-06	2.29e-05	6.19e-07	1.13e-06
F_5	SGA	4.71e-03	1.05e-03	7.20e-03	2.47e-03	6.57e-21
	DA	2.28e+00	1.13e+00	4.20e+00	4.44e-15	6.37e-12
	CSA	1.07e+00	9.21e-01	3.02e+00	1.75e-03	4.52e-06
	MVO	8.06e-02	2.04e-01	1.16e+00	1.17e-02	3.89e-02
	IMVO	4.27e-05	2.22e-05	1.04e-04	7.08e-06	1.98e-11
F_6	SGA	2.61e-05	2.30e-05	8.78e-05	3.56e-06	9.00e-07
	DA	9.78e-01	8.58e-01	3.49e+00	4.84e-03	8.12e-07
	CSA	3.83e-01	6.07e-01	3.20e+00	5.67e-05	1.69e-03
	MVO	1.07e-02	5.70e-02	3.12e-01	9.21e-05	3.09e-01*
	IMVO	1.25e-10	1.18e-10	4.45e-10	7.76e-12	2.82e-06

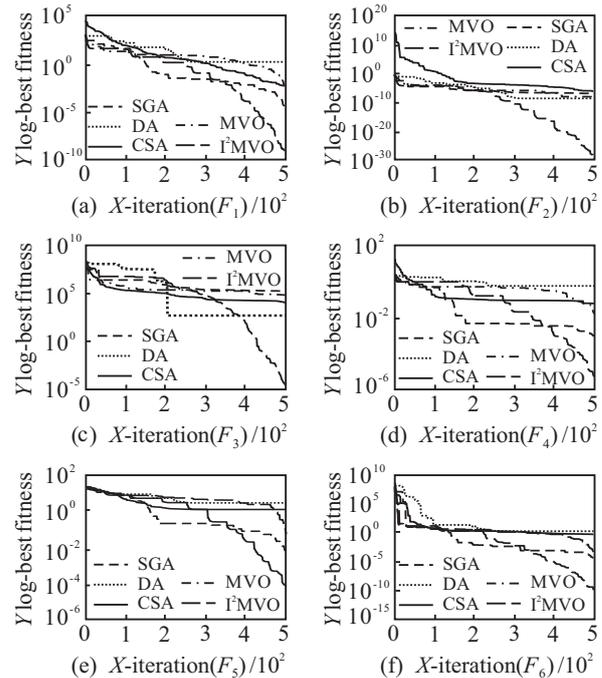


图4 不同智能算法的迭代寻优对比

由图4分析可知: 5种算法对6组测试函数的迭代寻优进程各不相同, 特别是后期差异性更为显著. I²MVO算法前期在5/6函数上全局搜索性能表现优异(除图4(c)), 随迭代进程其局部优化性能越趋增强, 达 L 时寻优精度已显著优于其他算法几个甚至十几个数量级, 直观地验证了改进算法的优越寻优性能; 同时, 在 L 处I²MVO算法的潜在寻优率明显高于其他算法, 表明改进算法仍保持较强的寻优态势.

综上所述: IMVO算法不仅在寻优精度上有显著

提升,而且能保持较强的寻优潜力,表明改进算法具有优越的优化能力和良好的局部极值规避性等,可有效提高传统MVO算法的寻优性能。

4 结论

为改善MVO算法的迭代寻优性能,本文分别从宇宙种群层级和最优宇宙个体层级迭代更新种群个体,提出一种耦合横纵向个体更新策略的改进MVO算法。数值实验表明,不同加权学习因子递变函数差异性影响IMVO算法的优化性能且以反S型改进算法性能最优异,对比实验验证了改进算法的优越寻优性能和良好局部极值规避性等。接下来的工作主要是针对性改进MVO算法以解决多目标、多约束、离散化等实际问题或融合其他智能算法的特定算子/机理等以构造优化性能更强的迭代优化算法。

参考文献(References)

- [1] Verma O P, Parihar A S. An optimal fuzzy system for edge detection in color images using bacterial foraging algorithm[J]. *IEEE Trans on Fuzzy Systems*, 2017, 25(1): 114-127.
- [2] Kanarachos S, Griffin J, Fitzpatrick M E. Efficient truss optimization using the contrast-based fruit fly optimization algorithm[J]. *Computers & Structures*, 2017, 182: 137-148.
- [3] Dudek G. Artificial immune system with local feature selection for short-term load forecasting[J]. *IEEE Trans on Evolutionary Computation*, 2017, 21(1): 116-130.
- [4] Eiben A E, Bäck T. Empirical investigation of multiparent recombination operators in evolution strategies[J]. *Evolutionary Computation*, 1997, 5(3): 347-365.
- [5] Goldberg D E. *Genetic algorithms in search, optimization and machine learning*[M]. New York: Addison-wesley, 1989: 41.
- [6] Kennedy J, Eberhart R. Particle swarm optimization[C]. *Proc of IEEE Int Conf on Neural Networks*. Perth: IEEE, 1995: 1942-1948.
- [7] Dorigo M. *Ant colony optimization for vehicle routing problem*[D]. Milan: System and Information Engineering, Politecnico di Milano, 1992.
- [8] Kirkpatrick S, Gelatt C D, Vecchi M P. Optimization by simulated annealing[J]. *Science*, 1983, 220(4598): 671-680.
- [9] Rashedi E, Nezamabadi-Pour H, Saryazdi S. GSA: A gravitational search algorithm[J]. *Information Sciences*, 2009, 179(13): 2232-2248.
- [10] Abedinpourshotorban H, Shamsuddin S M, Beheshti Z, et al. Electromagnetic field optimization: A physics-inspired metaheuristic optimization algorithm[J]. *Swarm and Evolutionary Computation*, 2016, 26: 8-22.
- [11] Goncalves M S, Lopez R H, Miguel L F F. Search group algorithm: A new metaheuristic method for the optimization of truss structures[J]. *Computers & Structures*, 2015, 153: 165-184.
- [12] Askarzadeh A. A novel metaheuristic method for solving constrained engineering optimization problems: Crow search algorithm[J]. *Computers & Structures*, 2016, 169: 1-12.
- [13] Mirjalili S. Dragonfly algorithm: A new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems[J]. *Neural Computing and Applications*, 2016, 27(4): 1053-1073.
- [14] Mirjalili S, Mirjalili S M, Hatamlou A. Multi-verse optimizer: A nature-inspired algorithm for global optimization[J]. *Neural Computing and Applications*, 2016, 27(2): 495-513.
- [15] Faris H, Aljarah I, Mirjalili S. Training feedforward neural networks using multi-verse optimizer for binary classification problems[J]. *Applied Intelligence*, 2016, 45(2): 322-332.
- [16] Mirjalili S. Dragonfly algorithm: A new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems[J]. *Neural Computing and Applications*, 2016, 27(4): 1053-1073.
- [17] 刘爱国, 崔宜兰. 倒S型曲线模型的研究[J]. *工科数学*, 1996, 12(2): 21-24.
(Liu A G, Cui Y L. Research on curve model of inverse S[J]. *J of Mathematics for Technology*, 1996, 12(2): 21-24.)
- [18] 唐若笠, 方彦军, 孔政敏. 一种深度扩展记忆的仿人粒子群算法仿真分析[J]. *控制与决策*, 2015, 30(4): 630-634.
(Tang R L, Fang Y J, Kong Z M. Simulation analysis of human simulated PSO based on deep extended memory[J]. *Control and Decision*, 2015, 30(4): 630-634.)

(责任编辑: 闫妍)